



# Düce Üniversitesi Bilim ve Teknoloji Dergisi

*Araştırma Makalesi*

## Myo-Elektriksel Sinyaller İle İnsansız Kara Aracının Uzaktan Kontrolü

 Beyda TAŞAR<sup>a,\*</sup>,  Ahmet B. TATAR<sup>a</sup>,  Özgür NAZLI<sup>a</sup>,  Osman KALKAN<sup>a</sup>

<sup>a</sup> Mekanik Bölümü, Mühendislik Fakültesi, Fırat Üniversitesi, Elazığ, TÜRKİYE

\* Sorumlu yazarın e-posta adresi: btasar@dfirat.edu.tr

DOI: 10.29130/dubited.606622

### ÖZET

Bu çalışma kapsamında insansız bir kara aracının kişinin el ve parmak hareketleri ile uzaktan kontrolü gerçekleştirilmiştir. Beyinden kol kaslarına iletilen ve kişinin el hareketlerini gerçekleştirmesini sağlayan Elektromiyografi (EMG) sinyalleri, kişinin koluna giydiği sekiz EMG sensör içeren bileklik vasıtası ile gerçek zamanlı olarak alınmıştır. Raspberry pi 3 gömülü sistem kartı üzerinde geliştirilen sinyal işleme, öznelik çıkarımı ve sınıflandırma algoritmaları kullanılarak anlaşılmıştır. Başka bir deyişle el hareketin örüntüsü (el kapama, parmak açma, serçe parmak temas, bilek dışa bükme, vs.) ile EMG sinyal grubu arasındaki ilişkiler tanımlanmıştır. Anlaşılmış her bir el hareketi araç için bir hareketi kontrol komutu (el kapama: araç ileri, parmak açma: araç dur, serçe parmağa temas: sola dönüş, bilek dışa bükme: sağa dönüş, vs.) olarak kullanılmıştır. Böylece insan – mobil araç etkileşim ağı kurulmuştur. Kurulan insan- mobil araç etkileşim ağı sayesinde el hareketleri ile mobil aracın gerçek zamanlı hareket kontrolü ortalama % 92 başarı ile gerçekleştirilmiştir.

**Anahtar Kelimeler:** Myo kol bandı, EMG sinyali, Hareket sınıflandırılması, Mobil araç kontrolü.

## Remote Control of Unmanned Ground Vehicle via Myo-Electrical Signals

### ABSTRACT

In this study, remote control of an unmanned land vehicle by hand and finger movements was performed. Electromyography (EMG) signals, which are transmitted from the brain to the arm muscles and enable the person to perform hand movements, were received in real-time by a wristband containing eight EMG sensors worn on the arm. The signal processing, developed on the Raspberry pi 3 embedded system board, was recognized by using feature extraction and classification algorithms. In other words, the relationship between the pattern of hand movement (hand closure, hand opening, thumb-pinky finger touch, wrist bending, etc.) and the EMG signal group is defined. For each recognized hand gesture was used as a motion control command for the vehicle (hand closure: vehicle forward, hand opening: vehicle stop, thumb-little finger touch: left turn, wrist bend: right turn, etc.). Thus, a human - mobile vehicle interaction network was established. Thanks to the established human-mobile vehicle interaction network, real-time motion control of hand movements and the mobile vehicle were achieved with an average success rate of 92%.

**Keywords:** Myo armband, EMG signal, Motion classification, Mobile vehicle control

## I. GİRİŞ

İnsan ve mobil cihazlar arasındaki etkileşim ağı konusu son yıllarda oldukça popüler araştırma alanlarından biridir. Bu çalışmanın konusunu ise teşkil eden el ve parmak hareketlerinin anlamlandırılması yolu ile mobil cihazlar için davranışsal bir komut tanımlama sistemidir. İnsan robot etkileşim ağı genellikle görsel tabanlı veya biyoelektriksel sinyal tabanlı hareket anlamlandırma yöntemleri kullanılarak gerçekleştirilir [1, 2]. Görsel-temelli el hareketi tanıma sistemi, kameralar vasıtası ile hareketin algılanması ve görüntü işleme teknikleri ile anlamlandırılması prensibine dayanır. [3]. Bu yöntemin temel dezavantajları el hareketinin üç boyutlu uzayda modellenmesindeki karmaşıklık ve ortamın aydınlatma koşullarının kötü olması durumunda sınıflandırma başarımının düşmesidir [4,5]. Elektromiyografi (EMG) tabanlı hareket tanıma sistemleri ise beyinden kaslara iletilen impuls sinyallerinin hareket esnasında alınıp, işlenmesi ve makine öğrenmesi algoritmaları ile anlamlandırılması prensibine dayanır [6]. Biyoelektriksel sinyallerin anlamlandırılması yolu ile kontrol edilen tekerlekli sandalyeler [6-8] ve mobil robotlar[9,10] ve bazı özel sistemler literatürde mevcuttur. [11-13].

Biyoelektriksel sinyaller kişinin hareketi hakkında bazı bilgileri (Sinirsel aktiviteyi oluşturan motor ünitenin tepki hızı, dolma ve boşalma şekli ve süresi, biyoelektriksel sinyalin maksimum genliği, enerjisi, salınım miktarı ve frekansı vs.) bünyesinde barındırır. Ve bu bilgiler kişinin hareket türüne göre farklılık göstermektedir. Bu nedenle EMG sinyalleri vasıtası ile el hareketlerinin sınıflandırılması ve insan robot etkileşim ağı kurulumu için kullanımı başarılı sonuçlar vermektedir.

EMG sinyalleri vasıtası ile hareket türünün anlamlandırılması konusu literatürde üç ana başlığa ayrılarak incelenmiştir. Bunlar sırası ile sinyalin ön işlemden geçirilmesi, özneliklerinin çıkarımı ve sınıflandırması konularıdır. Literatür incelendiğinde, neredeyse tüm çalışmalarda, ön işlem adımlarının oldukça benzer olduğu ve çevresel ve donanımsal gürültü etkisini ortadan kaldırmak için bant geçiren bir filtre kullanıldığı görülmektedir. Bununla birlikte, öznelik çıkarma ve sınıflandırma aşamalarında araştırmacılar farklı yaklaşımlar ve yöntemler kullanmışlardır [17]. Sınıflandırma algoritmasına ham EMG sinyali uygulandığında sınıflandırıcı performansı çok düşük olduğundan araştırmacılar, performansı iyileştirmek amacı ile sınıflandırıcıya EMG sinyalinin farklı özneliklerini (Zaman etki alanı özneliklerinden: Ortalama değer, ortalama eğim, sinyalin sıfır geçiş sayısı ve Frekans etki alanı özneliklerinden: ortalama frekans, güç spektrumu vs. [18-20]) hesaplayıp, girdi olarak vermişlerdir. Yaptıkları bir çalışmada [21-26] araştırmacılar yapay sinir ağı sınıflandırıcıyla zaman etki alanı özneliklerini ve frekans etki alanı özneliklerini hesaplamış ve girdi olarak ayrı ayrı vermişlerdir. Sonuçlara göre zaman etki alanı öznelikleri ile % 78.3, frekans alanı öznelikleri ile % 62.5'lik bir hareket sınıflandırma başarısı sağlandığı ifade edilmiştir. [21]. Bu karşılaştırma sonucuna ek olarak biyomedikal sinyal uygulamalarında, hesaplama kolaylığı nedeni ile zaman alanı özelliklerinin tercih edildiği ve zaman alanı özelliklerinin gürültülü ortamlarda sinyal sınıflandırma performansı açısından daha iyi sonuçlar verdiği bilinmektedir.

EMG sinyalleri aracılığı ile hareket türünün tespiti uygulamalarında sıklıkla kullanılan makine öğrenmesi algoritmaları ise Yapay Sinir Ağları (YSA), bulanık sınıflandırıcı, karar ağacı algoritması, rastgele orman algoritması, bayes algoritmaları ve Destek Vektör Makineleridir (DVM'ler) [14]. Bazı araştırmacılar, DVM sınıflandırıcılarını basitlikleri ve eğitim kolaylıkları nedeniyle [16,17].bir kısım araştırmacılar ise yapay sinir ağı sınıflandırma algoritmasını hem doğrusal hem de doğrusal olmayan sistemlerde kullanılabildiği için tercih etmişlerdir. [18]. Bazı araştırmacılar ise EMG verilerini kontrolsüz bir öğrenme tekniğiyle öğretmek ve test verilerini otomatik olarak tanımak için çok katmanlı perceptron tipi yapay sinir ağları ağını önermişlerdir. [19]. Tsuji ve arkadaşları geri yayılım yapay sinir ağı modeli ile kaydedilen biyoelektrik sinyallerin entropisini kullanarak altı e sınıflandırdılar [20]. Khezri ve arkadaşları ise yapay sinir tabanlı bulanık mantık sınıflandırma algoritması kullanmıştır[23]. Subaşı ve arkadaşları geri yayılım yapay sinir ağını ve dalgacık sinir ağını birlikte kullanılmasını önerilmiştir [24]. Christodoulou ve arkadaşları ise KNN, SOM ve SVM sınıflandırma algoritmalarını kullanarak sınıflandırma performanslarını karşılaştırdılar. Sonuçlar,

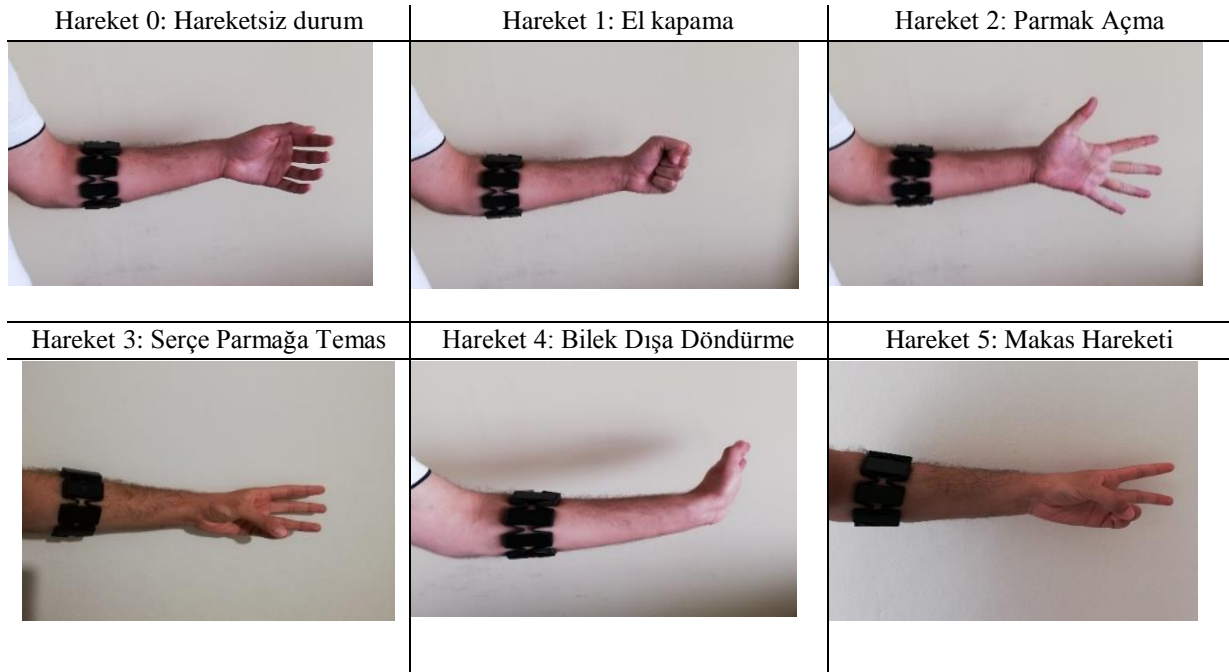
öğrenme hızı yavaş olmasına rağmen, SVM algoritmasının sınıflandırmada en başarılı olduğunu göstermiştir [26].

## **II. YÖNTEM VE METODLAR**

### **A. ÇALIŞMAYA GENEL BAKIŞ**

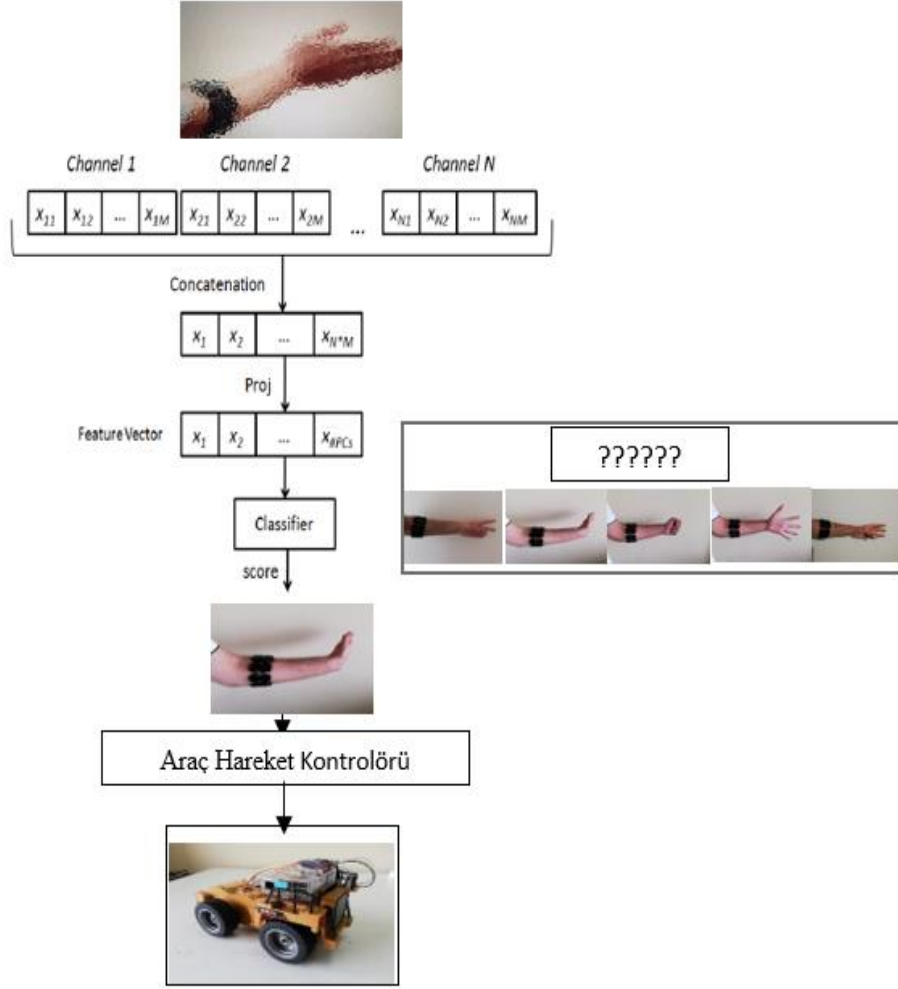
Bu çalışmanın konusu, mobil bir kara aracının uzaktan kontrolünün sağlanması amacı ile insan-robot etkileşim ağının kurulmasıdır. İstemli el hareketlerini sağlamak için beyinden kol kaslarına iletilen biyoelektrik sinyaller, bileklik şeklindeki EMG sensörler vasıtası ile kaydedilmiş, makine öğrenmesi algoritmaları ile anlamlandırılmıştır. Anlamlandırılan her bir el hareketi mobil robot için bir hareket komutu olarak tanımlanmıştır yani insan – robot etkileşim ağının kurulmuştur. Sonuç olarak mobil aracın gerçek zamanlı kontrolünü el hareketleri ile sağlanmıştır.

İnsan eli çok sayıda bağımsız ekleme ve dolayısı ile harekete türüne sahiptir. Ancak aracın kontrolü için altı farklı el hareketinin anlamlandırılması ve aracın hareket türü ile ilişkilendirilmesi yeterli olacaktır. Şekil 1’de insan-mobil araç etkileşim ağının kurulumu için seçilen el hareketleri görülmektedir. El kapama hareketi aracı ileriye doğru hareket ettirmek, parmak açma hareketi aracı durdurmak, serçe parmağa temas hareketi aracı sola döndürmek, el dışı bükme hareketi aracı sağa döndürmek, makas hareketi ise aracı geri yönlü hareket ettirmek için seçilmiş hareketlerdir.




*Şekil 1. İnsan-mobil araç etkileşim ağının kurulumu için seçilen el hareketleri*

Çalışmaya ait blok diyagramı Şekil 2’de yer almaktadır. Myo bileklik üzerinde yer alan sekiz adet EMG sensörden (sekiz kanal), sekiz adet sinyal verisi alınmış, literatürde sınıflandırmada en yüksek doğrulukta sonuç ürettiği vurgulanan üç zaman alanı özneliği (sinyalin enerjisi, maksimum genliği, ortalama değeri) sekiz sinyal için ayrı ayrı hesaplanmış ve en yüksek sınıflandırma başarısına sahip olduğu bilinen DVM sınıflandırma algoritmasına girdi olarak verilmiştir. Araç kontrol bloğunda ise kişinin her bir el hareketi araç için birer yönelim komutu olarak tanımlanıp, gelen hareket türüne göre araç motorları kontrol edilmiştir.



Şekil 2. Çalışmanın yöntemine genel bakış

Sistemin donanım yapısı Şekil 3'te yer almaktadır. Sistem kişinin el hareketleri esnasında oluşan biyoelektriksel sinyalleri kaydetmek için sekiz adet EMG sensör içeren bir adet myo kol bandı, sinyal işleme ve sınıflandırma algoritmalarının geliştirilmesi için bir adet Raspberry Pi gömülü sistem kartı, 1:18 ölçekli bir mobil kara aracı, motor sürücü kartı ve LiPo bataryadan oluşmaktadır. Algoritmalar Raspberry Pi gömülü kartında linux işletim sistemi üzerinde, Python dilinde yazılmıştır.




Şekil 3. Sistemin donanım yapısına genel bakış

## B. KAYIT SAFHASI

Çalışmada 22-26yaş aralığında iki adet gönüllü katılımcı bulunmaktadır. (iki erkek.) Katılımcılar, uygulama esnasında Thalmic Firması tarafından üretilen (Şekil 4) myo sensör kol bandını giymişlerdir (Şekil1). Katılımcılar, Şekil 2’de yer alan el hareketlerin gerçekleştirirken alt kol kaslarına ait sinirsel aktivite verileri kaydedilmiştir. EMG sinyalleri 200 Hz’lik örnekleme frekansı ile örneklenecek alınmıştır. Myo-kol bandı üzerinde bulunan standart Bluetooth Düşük Enerji frekansında (2.402-2.480 GHz) çalışan bir bluetooth verici sayesinde EMG sinyal grubunu Raspberry pi 3 gömülü sistem kartına iletilmektedir. Şekil 5’te el kapama hareketi için kaydedilmiş örnek bir EMG sinyal grubuna yer almaktadır.



Şekil 4. Myo Kol bandı




Şekil 5. Myo-kol bandından alınan örnek bir EMG sinyal grafiği (el kapama hareketi)

## C. ÖN İŞLEME VE ÖZNETELİK ÇIKARIMI

Biyolektriksel sinyaller (EMG); nöromüsküler aktiviteler hakkında değerli bilgileri bünyesinde barındırmaktadır. EMG sinyali ne periyodik ne de deterministiktir [14]. EMG sinyalleri belirli zaman aralıklarında tekrarlanmaz ve tek bir matematiksel ifade, bir kayıt periyodu sırasında elde edilen EMG sinyallerini temsil edemez [15]. EMG sinyalleri sabit sinyaller değildir. EMG sinyalinin kaydı sırasında, ortam gürültüsü, manyetik etkiler ve elektronik kayıt cihazından gelen ses, ham EMG sinyaline karışabilir ve sinyalin yanlış yorumlanmasına neden olabilir. Bu nedenle yapılan çalışmalarda sinyale sırası ile önce ön işleme (filtreleme, pencerelere ayırma) sonrasında özellik çıkarımı ve sinyal anlamlandırma teknikleri uygulanmaktadır. [16] Bu çalışma kapsamında da bu sıralamaya uyulmuştur ve sinyal önce 50- 150 Hz aralığında bant geçiren bir filtreden geçirilmiştir.

Gerçek zamanlı sinyal işleme uygulamalarında sinyale pencereleme işlemi uygulanır. Pencereleme işlemi için iki farklı yöntem kullanılabilir. Bu uygulamada komşu (adjacent) yöntemi uygulanmıştır.

Bu yöntemde, sinyaller R ms'lik paketlere ayrılmıştır ve her bir paketin ile önceki paket ile arasındaki çakışma r ms dir. Gerçek zamanlı uygulamalar için genel kabul gören optimum pencereleme değerleri olan “R =256 msn, r =32 msn” değerleri bu çalışma için uygulanmıştır (Şekil 6).



Şekil 6. Sinyalin pencereleme ayrıştırılması

256 ms'lik parçalara (pencereleme) ayrılmış her bir sinyal grubuna zaman etki alanı öznelik çıkarım yöntemleri uygulandı ve sinyalin enerjisi, maksimum değerini ve ortalama değeri hesaplanmıştır. Sinyallerin hesaplanan özneliklerine ait matematiksel ifadeleri;

*Sinyalin Enerjisi:*  $m(t)$  sinyalinin enerjisi eşitlik (1) ile hesaplanır. Burada  $t_j$  ve  $t_i$ , sinyalin integrasyonu yapılacak olan kısmının alt ve üst zaman sınırlarını göstermektedir.

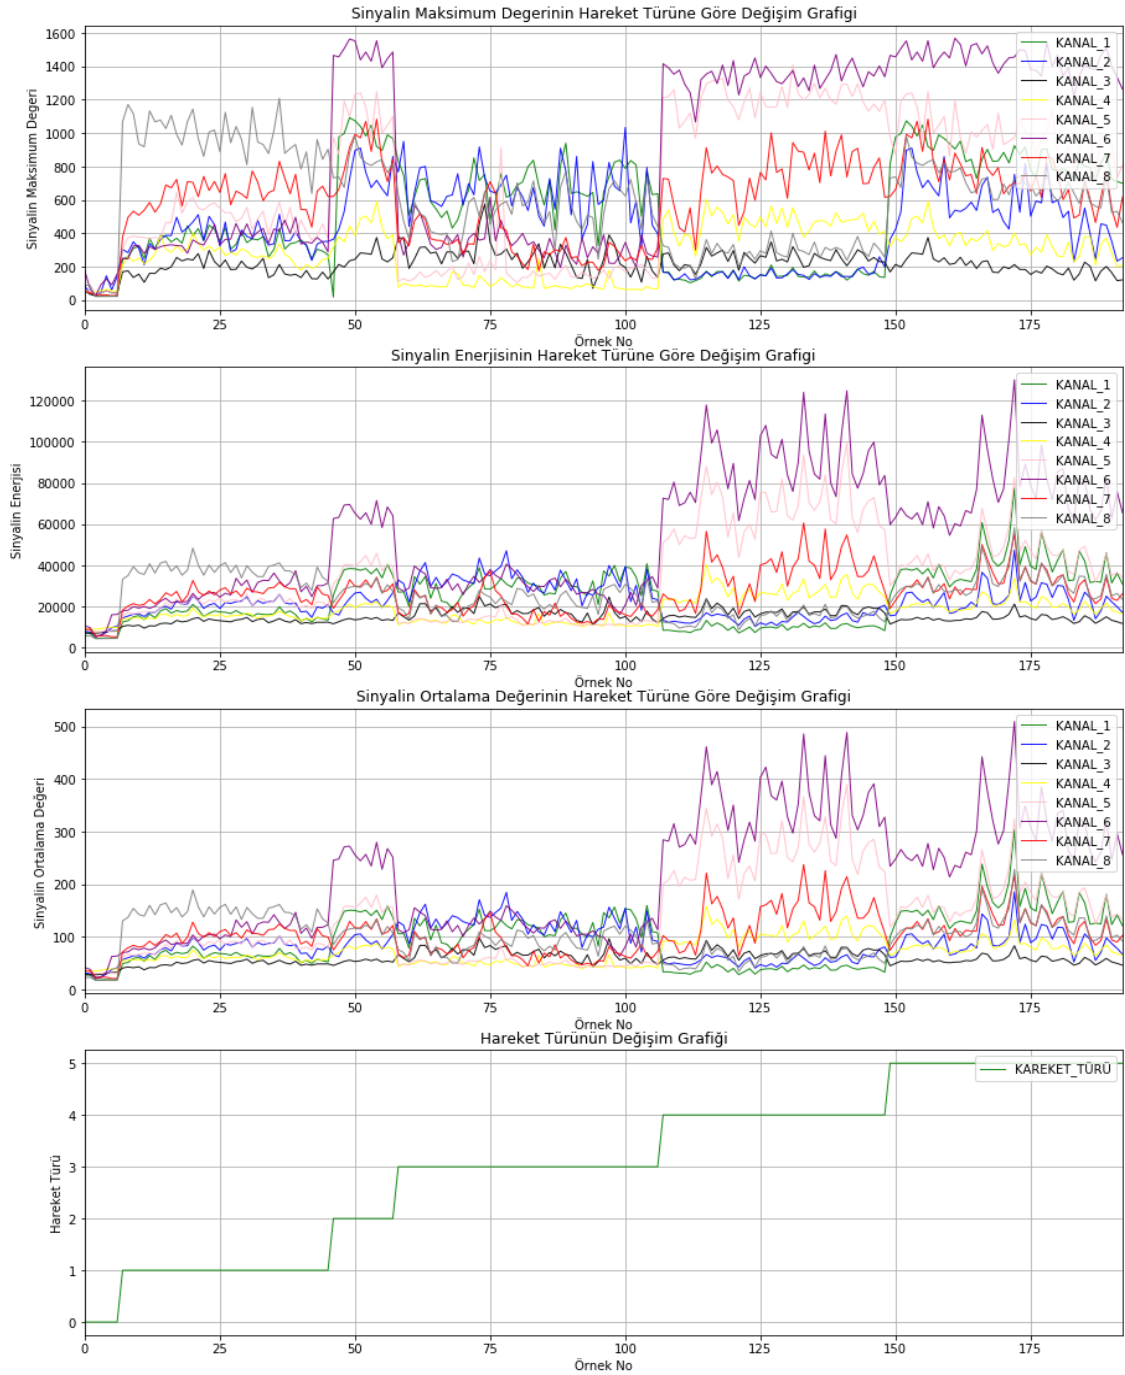
$$E = \int_{t_i}^{t_j} |m(t)| dt \quad (1)$$

*Sinyalin Maximum Değeri:* Pencereleme bölünmüş her bir paketindeki örneklenmiş sinyal değerlerinden en büyük olanını ifade etmektedir.

*Sinyalin Ortalama Değeri:* Pencereleme bölünmüş her bir paketindeki örneklenmiş sinyalin ortalama değeri eşitlik (2) ile hesaplanır.

$$E = \frac{1}{t_j - t_i} \int_{t_i}^{t_j} |m(t)| dt \quad (2)$$

Sekiz kanallı sinyal grubundan hesaplanan öznelik bilgisi vektör formatındadır yani 1 x 24 (8 kanal x 3 öznelik) boyutundadır. Çalışma kapsamında iki kişiden beş farklı el hareketi için 50 şer tekrarlı olarak öznelik veri seti hesaplanmıştır. Toplam veri boyutu 500x24 boyutundadır. Şekil 7'de hareket türlerine göre hesaplanan EMG özneliklerinin değişimini gösteren örnek bir grafik yer almaktadır.



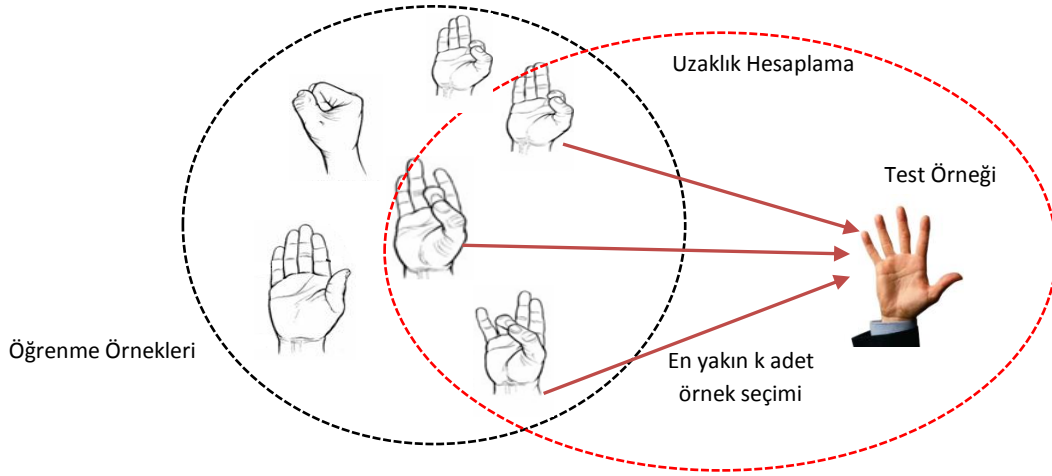
*Şekil 7. Seçilen beş el hareketine göre EMG özneliklerinin değişimini*

#### **D. EMG SİNYALLERİ VASITASI İLE EL HAREKETLERİNİN ANLAMLANDIRILMASI**

Biyoelektriksel sinyaller vasıtası ile el örüntülerinin sınıflandırılması için beş ayrı sınıflandırma algoritması (karar ağacı, naif bayes, en yakın komşu rastgele orman, destek vektör makinası algoritmaları) kullanılmıştır. Alınan veri setinin %70'i eğitim ve % 30 'u test verisi olarak ayrılmıştır. Dört sınıflandırma algoritmasının da başarımları karşılaştırılmıştır. İkinci adım olarak kayıtlı veri seti üzerinde en yüksek sınıflandırma başarısına sahip olduğu tespit edilen destek vektör makinası algoritması, mobil aracın gerçek zamanlı kontrol uygulamasında tercih edilmiş ve kullanılmıştır.

Kullanılan sınıflandırma algoritmalarının tasarım adımları ayrıntılı olarak alt başlıklar halinde özetlenmiştir.

*En yakın komşu algoritması (KNN):* KNN, denetimli öğrenmede sınıflandırma ve regresyon için kullanılan algoritmalarından biridir. En basit makine öğrenmesi algoritması olarak kabul edilir. KNN algoritmasının temel çalışma mantığı, bilinmeyen yeni ve sınıflandırılmak istenilen noktanın, sınıflandırıcıyı eğitmek için kullanılan noktalar ile arasındaki mesafeyi hesaplayıp, yakınında hangi sınıfa ait daha çok nokta varsa, bilinmeyen nokta yakın olan sınıfa aittir prensibine dayanır. Burada önemli olan, bilinmeyen noktanın etrafında kaç noktanın referans alınıp karar verileceğidir çünkü bu değer algoritmanın karar hızını ve doğruluğu etkileyen en temel faktördür[22].



**Şekil 8.** KNN Sınıflandırma algoritmasının tasviri

Bu çalışmada KNN algoritmasının karar vermek için test örneğine en yakın üç örnek referans alınmıştır yani  $k=3$  seçilmiştir (Şekil 8). Mesafe hesaplaması için Öklid uzaklık formülü kullanılmıştır. Çalışma hızı ve karar doğruluğu test edilmiş ve bu değerlerin uygun olduğuna karar verilmiştir.

*Karar ağacı Algoritması:* Karar ağaçları sınıflama, özellik ve hedefe göre karar düğümleri (decision nodes) ve yaprak düğümlerinden (leaf nodes) oluşan ağaç yapısı formunda bir sınıflandırma yöntemidir. Karar ağacı algoritması, veri setini küçük ve hatta daha küçük parçalara bölerek geliştirilir. Bir karar düğümü bir veya birden fazla dallanma içerebilir. İlk düğüme kök düğüm (root node) denir. Biyoelektriksel sinyallerin - sınıflandırma işlemi için uygun bir algoritmadır.

*Rasgele Orman Algoritması:* Denetimli bir öğrenme algoritmasıdır. Adından da anlaşıldığı gibi karar ağaçlarından bir orman oluşturur ve bunu rastgele bir şekilde yapar. Oluşturduğu "orman", "torbalama" yöntemiyle eğitilmiş karar ağaçları topluluğudur. Torbalama yönteminin genel fikri, öğrenme modellerinin bir kombinasyonunun genel sonucu artırmasıdır. Rastgele Orman, hiper-parametresi olmadan bile, çoğu zaman çok doğru sonuçlar veren esnek, kullanımı kolay bir makine öğrenme algoritmasıdır. Basit yapısı ve hem sınıflandırma hem de regresyon görevlerine uygun yapıda olduğu için kullanılan algoritmalarından biridir.

*Destek Vektör Makinası Algoritması:* Destek Vektör Makinası algoritması istatistiksel öğrenme teorisine dayanır. Destek Vektör Makinelerinin çalışma prensibi, temel olarak iki sınıfa ait verileri birbirinden en uygun şekilde ayırmak için karar sınırları ya da diğer bir ifadeyle hiper düzlemler belirlemektir. İki sınıf için tasarlanan bu algoritma daha sonra çok sınıflı sınıflandırma problemleri için genelleştirilmiştir [28,29]. Bu çalışmada sınıflandırma problemimiz beş farklı sınıftan oluşmaktadır. Bu nedenle, "bire-bir" yaklaşımı [30] çok-sınıflı DVM sınıflandırıcı tasarımı yapılmıştır.



## E. İNSANSIZ KARA ARACININ KONTROL STRATEJİSİ

Kontrolü gerçekleştirilen aracın (Şekil 9) boyutları 15x 15.5 x 28 cm olup, dört tekerlekli ve ağırlığı kontrolör kartı, LiPo bataryada dâhil yaklaşık 1kg'dır. Araçta iki adet DC motor bulunmaktadır. Sağ ve sol arka tekerlekler doğrudan DC motorlara bağlı iken ön motorlara tahrik, dişli sistemi ile iletilmektedir. Aracın yönü, her bir tekerleğin hızının bileşimi ve ICC — Ani Eğrilik Merkezi (veya ICR — Ani Rotasyon Merkezi) olarak adlandırılan ortak eksen üzerinde bulunan bir nokta etrafında rotasyon ile ilişkilidir.



Şekil 9. a) Mobil aracın yandan ve perspektif görünüşü ve b) mobil aracın hareket analizi

Şekil 9 b)'de yer alan mobil aracın hareket analizi görseli referans alındığında motor gerilimlerine göre hareket kontrolü aşağıdaki gibi analiz edilebilir.

$V_{sol} = V_{sağ}$  ise, bu düz bir çizgide doğrusal harekettir.

$R$  in nite olur ve  $\omega$  sıfırdır ve dönüş yoktur.

$V_{sol} = V_{sağ} = 0$  ise, araç durur

Eğer  $V_1 > V_2$  ise sol tekerlek daha hızlı döneceğinden araç sola döner.

Eğer  $V_2 > V_1$  ise, sağ tekerlek daha hızlı döneceğinden, araç sağa döner.


El hareketleri ile araç hareketi arasındaki ilişkiler ise Tablo'1 de özetlenmiştir.

Tablo 1. El hareket türü ve araç hareket ilişkisi

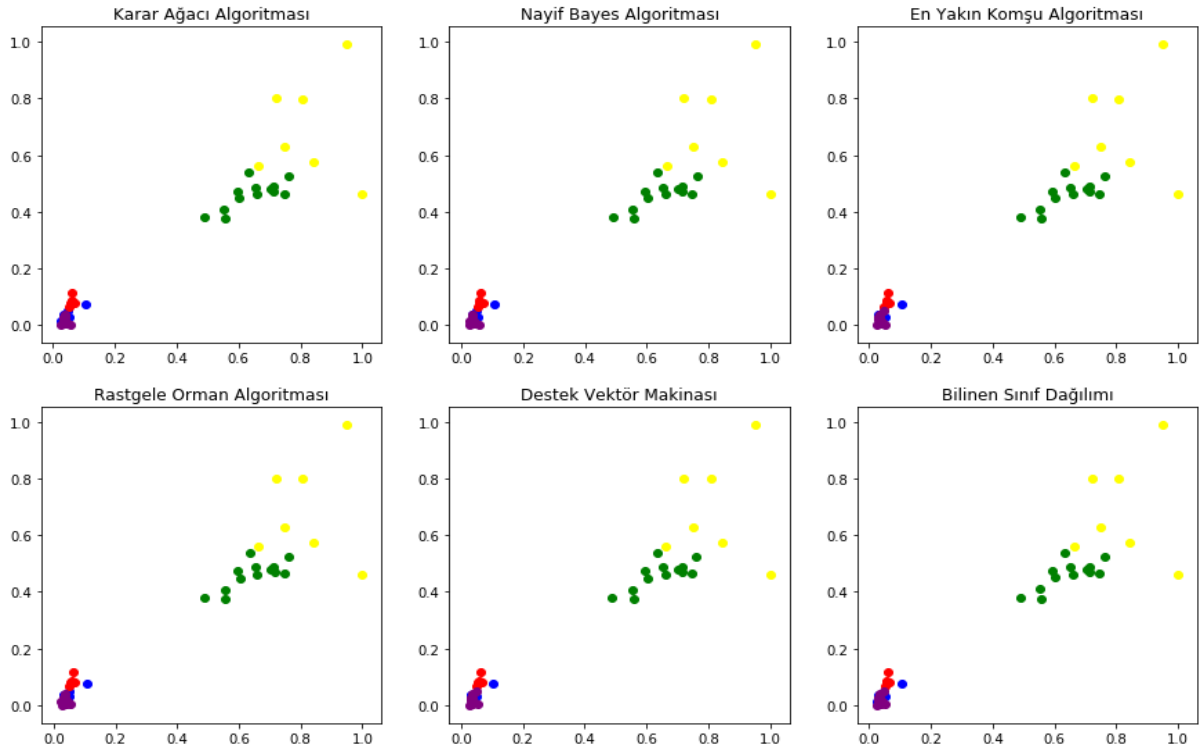
El hareketleri	Araç için hareket tanımlaması
Hareket 1: El kapama	İleriye doğru hareket ( $V_1$ ve $V_2$ motor gerilimleri eşit)
Hareket 1: Parmak Açma	Durma ( $V_1$ ve $V_2$ motor gerilimleri sıfıra eşittir)
Hareket 1: Serçe Parmağa Temas	Sola Dönme ( $V_1 > V_2$ )
Hareket 1: El Dışa Bükme	Sağa Dönme ( $V_2 > V_1$ )
Hareket 1: Makas Hareketi	Geri Gitme

## III. SONUÇLAR VE TARTIŞMA

Kayıt safhasında iki kişiden belirlenen beş hareket için 50 şer tekrarlı olarak sekiz kanallı EMG sensör vasıtası ile alınan biyo-elektriksel sinyal grubunun üçer adet zaman etki alanı öznelikleri hesaplanmış ve öznelilik veri setleri oluşturulmuştur. Sonrasında bu veri setinin %70'i eğitim amacı ile %30 'u test amacı ile kullanılmak üzere ayrılmıştır. Karar ağacı, navie bayes, en yakın komşu, rastgele orman, destek vektör makinası sınıflandırma algoritmalarının sınıflandırma başarıları test verisi kullanılarak karşılaştırılmıştır. Şekil 11 ve 12'de her sınıflandırıcının başarı grafikleri ve Tablo 2'de ise yüzdesel olarak ortalama başarı değerleri yer almaktadır. (Hareket Sınıf [0:5]: sarı, mavi, kırmızı, yeşil, mor, siyah )



**Şekil 11.** Sınıflandırma algoritmalarının başarımlarını grafiği (Kullanıcı 1'den alınan EMG sinyaller için)



**Şekil 12.** Sınıflandırma algoritmalarının başarımlarını grafiği (Kullanıcı 2'den alınan EMG sinyaller için)

**Tablo 2.** Sınıflandırma algoritmalarının başarısı karşılaştırma tablosu

	Karar Ağacı Algoritması	Naif Bayes Algoritması	KNN Algoritması	Rastgele Orman Algoritması	Destek Vektör Makinası Algoritması
Kullanıcı 1	0.844	0.879	0.879	0.862	0.948
Kullanıcı 2	0.981	0.962	0.981	0.962	0.981
Ortalama Başarı	0.912	0.920	0.930	0.912	0.964

Test başarısı en yüksek olan DVM algoritması, insansın kara aracının gerçek zamanlı olarak gerçekleştirilen kontrolünde kullanılmak için seçilmiştir. Yüzü aşkın hareket için yapılan online testler sırasında ise yaklaşık % 92’lik bir başarımla mobil kara aracın gerçek zamanlı hareket kontrolü, operatörün el hareketleri ile sağlanmıştır (Şekil 13).



**Şekil 13.** Çalışmaya ait fotoğraf

**TEŞEKKÜR:** Bu çalışma 2209-A TÜBİTAK- Üniversite Öğrencileri Araştırma Projeleri Destekleme Programı kapsamında desteklenmiştir. Ayrıca bu proje TUBİTAK 2242 Lisans Projeleri Bölge Yarışmalarında Bilişim Teknolojileri alanında ikincilik ödülüne layık görülmüştür.

## **V. KAYNAKLAR**

- [1] B. K. Chakraborty, D. Sarma, M. K. Bhuyan, K. F. MacDorman, “Review of constraints on vision-based gesture Recognition for human-computer interaction”. *IET Computer Vision*, vol.12, pp. 3–15, 2017.
- [2] A. Pasarica, C. Miron, D. Arotaritei, G. Andruseac, H. Costin, “Rotariu, Remote control of a robotic platform based on hand gesture recognition”, *In Proceedings of the E-Health and Bioengineering Conference (EHB)*, Sinaia, Romania, 22–24 June 2017; pp. 643–646.

- [3] H. Abualola, H. Al Ghothani, A.N. Eddin, N. Almoosa, K. Poon, “Flexible gesture recognition using wearable inertial sensors”. In *Proceedings of the IEEE 59th International Midwest Symposium on Circuits and Systems (MWSCAS)*, Abu Dhabi, UAE, 16–19 October 2016; pp. 1–4.
- [4] A.I. Maqueda, C.R. del-Blanco, F. Jaureguizar, N. García, “Human-computer interaction based on visual hand-gesture recognition using volumetric spatiograms of local binary patterns”, *Computer Vision and Image Understanding*, vol.141, pp.126–137, 2015.
- [5] S.A. Rahman, I. Song, M.K. Leung, I. Lee, K. Lee, “Fast action recognition using negative space features,” *Expert System Application*, vol. 41, pp. 574–587, 2014.
- [6] V. Gandhi, T.M. McGinnity, “Quantum neural network-based surface EMG signal filtering for control of robotic hand”. In *Proceedings of the IEEE International Joint Conference on Neural Networks*, Dallas, TX, USA, 4–9 August 2013.
- [7] I. Moon, M. Lee, J. Ryu, M. Mun, “Intelligent robotic wheelchair with EMG, gesture, and voice-based interfaces”. In *Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS 2003)*, Las Vegas, NV, USA, 27–31 October 2003; pp. 3453–3458.
- [8] G. Kucukyildiz, H. Ocak, S. Karakaya, O. Sayli, “Design and implementation of a multi-sensor based brain-computer interface for a robotic wheelchair”. *Journal of Intelligent and Robotic Systems*, vol. 87, pp. 247–263, 2017.
- [9] S. Shin, D. Kim, Y. Seo, “Controlling mobile robot using IMU and EMG sensor-based gesture recognition”. In *Proceedings of the Ninth International Conference on Broadband and Wireless Computing, Communication and Applications (BWCCA)*, Guangdong, China, 8–10 November 2014; pp. 554–557.
- [10] G.C. Luh, H.A. Lin, Y.H. Ma, C.J. Yen, “Intuitive muscle-gesture based robot navigation control using wearable gesture armband”. In *Proceedings of the International Conference on Machine Learning and Cybernetics (ICMLC)*, Guangzhou, China, 12–15 July 2015; pp. 389–395.
- [11] V. Gandhi, “Brain-Computer Interfacing for Assistive Robotics: Electroencephalograms, Recurrent Quantum Neural Networks, and User-Centric Graphical Interfaces”, *Academic Press: Cambridge, MA, USA*, 2014.
- [12] V. Gandhi, G. Prasad, D. Coyle, L. Behera, T.M. McGinnity, “EEG based mobile robot control through an adaptive brain-robot interface”, *IEEE Transactions on Systems, Man, and Cybernetics: Systems*. vol. 44, pp. 1278–1285, 2014.
- [13] V. Gandhi, G. Prasad, D. Coyle, L. Behera, T.M. McGinnity, “Quantum neural network-based EEG filtering for a Brain-computer interface”. *IEEE Transactions on Neural Networks and Learning Systems*, vol. 25, pp. 278–288, 2014.
- [14] I. Rodriguez, A. Malanda, L. Gila, “Filter design for cancellation of baseline – fluctuation in needle EMG recordings”, *Computer Methods and Programs in Biomedicine*, vol. 81, pp. 79-93, 2006.
- [15] M.B.I. Raez, M.S. Hussain, and F. Mohd-Yasin, “Techniques of EMG signal analysis: detection, processing, classification and applications”, *Biological Procedures Online*, vol.8, pp. 11–35, 2006.
- [16] A.P. Dobrowolski, M. Wierzbowski, K. Tomczykiewicz, “Multi-resolution MÜAPs decomposition and SVM based analysis in the classification of neuromuscular disorders”, *Computer Methods and Programs in Biomedicine*, Elsevier, 2010.

- [17] N. D. Pagniotacopulos, J. S. Lae, M. H. Pope, "Evaluation of EMG signals from rehabilitated patients with low back pain using wavelets", *J. Electromyography and Kinesiology*, vol. 8, pp.269 – 278, 1998.
- [18] B. Hudgins, P. Parker, R.N. Scott, "A new strategy for multifunction myoelectric control", *IEEE Transactions on Biomedical Engineering*, vol. 40, pp. 82–94, 1993.
- [19] K. Englehart, B. Hudgins, P. Parker, "Multifunction Control of Prostheses Using the Myoelectric Signal". In *Intelligent Systems and Technologies in Rehabilitation Engineering*; Teodorescu, H.-N.L. Jain, L.C. Eds.; CRC Press: New York, NY, USA, 2000.
- [20] K. Englehart, B. Hudgins, "A robust, real-time control scheme for multifunction myoelectric control". *IEEE Transactions on Biomedical Engineering*. vol. 50, pp. 848–854, 2003.
- [21] M. B. I. Reaz, M. S. Hussain and F. Mohd-Yasin, "Techniques of EMG signal analysis: detection, processing, classification and applications", *Biological Procedures Online*, vol:8(1), pp.11-3, doi:10.1251/bpo115, March 23, 2006.
- [22] M.J. Islam, Q.J. Wu, M. Ahmadi, M.A. Sid-Ahmed, "Investigating the performance of naive-bayes classifiers and k-nearest neighbor classifiers". In *Proceedings of the International Conference on Convergence Information Technology*, Gyeongju, Korea, 21–23 November 2007; pp. 1541–1546.